

ӘОЖ 004.93
ГТАХР 28.23.15

<https://doi.org/10.55452/1998-6688-2025-22-4-119-130>

¹**Есмұхамедов Н.С.,**
докторант, ORCID: 0009-0006-0652-3082,
e-mail: yesmukhamedov.yeskendyr@gmail.com
^{1*}**Сапақова С.З.,**
ф.-м.ғ.к., қауымдастырылған профессор, ORCID ID: 0000-0001-6541-6806,
*e-mail: sapakovasz@gmail.com
²**Қожамкулова Ж.Ж.,**
PhD, қауымдастырылған профессор, ORCID ID: 0000-0002-9780-9767,
e-mail: zh.kozhamkulova@aes.kz
³**Даниярова Д.Р.,**
т.ғ.к., қауымдастырылған профессор, ORCID: 0000-0002-6833-6462,
e-mail: duriya.daniyarova@mail.ru
¹**Арманкызы Р.,**
магистр, лектор, ORCID ID: 0009-0009-2236-559X,
e-mail: armankyzyrenata@gmail.com

¹Халықаралық ақпараттық технологиялар университеті, Алматы қ., Қазақстан

²Г. Дукеев атындағы КЕАҚ АЭЖБУ, Алматы қ., Қазақстан

³Халықаралық білім беру корпорациясы, Алматы қ., Қазақстан

ДИАБЕТТІК РЕТИНОПАТИЯНЫ АНЫҚТАУДА КӨЗ ТҮБІ СУРЕТТЕРІН АЛДЫН АЛА ӨНДЕУ ЖӘНЕ ТАЛДАУ ӘДІСТЕРІ

Аңдатпа

Бұл жұмыс диабеттік ретинопатияны анықтауға арналған көз түбі суреттерін алдын ала өңдеу және талдау әдістерін зерттеуге арналған. Диабеттік ретинопатия (ДР) – қант диабетімен ауыратын науқастарда жиі кездесетін көз ауруы, және оның ерте диагностикасы көру қабілетінің жоғалуын болдырмауға мүмкіндік береді. Зерттеу барысында көз түбі суреттерін өңдеу мен талдау үшін заманауи әдістер, соның ішінде Deep Learning негізінде құрылған EfficientNetB0 архитектурасы қолданылды. Алдын ала өңдеу үшін сурет аугментациясы (айналдыру, масштабтау, кесу, контрастты арттыру) және нормализация әдістері енгізілді. EfficientNetB0 архитектурасын пайдалану барысында екі тәсіл сыналды: базалық қабаттарды қатырып оқыту және жоғарғы қабаттарды ашу арқылы қосымша бейімдеу (fine-tuning). Нәтижелер метрикалар бойынша бағаланды. Бірінші әдісте тест жиыны үшін дәлдік (precision) 65%, екінші әдісте 75% болды. Бірінші әдіс бойынша валидациялық жиынның дәлдігі 63%, ал екінші әдіс бойынша 71% жетті. Қайталауды анықтау (recall) метрикасы бірінші әдісте тест жиыны үшін 60%, екінші әдісте 74% көрсетті. Жалпы, fine-tuning әдісінің көрсеткіштері жоғары болды. Бұл әдістерді пайдалану диабеттік ретинопатияны тиімді диагностикалау үшін суреттерді өңдеу мен классификациялаудың сапасын арттыруға мүмкіндік береді. Зерттеудің жаңашылдығы – тиімділігі жоғары EfficientNetB0 архитектурасын қолдану және бейімдеудің әртүрлі тәсілдерін талдау. Алынған нәтижелер ДР диагностикасында автоматтандырылған жүйелердің сапасын жақсартуға және модельдің энергия тиімділігін арттыруға мүмкіндік береді. Ұсынылған әдістер көз ауруларын ерте кезеңде анықтауда жоғары потенциалға ие.

Тірек сөздер: диабеттік ретинопатия, машиналық оқыту, деректерді талдау, лазерлік коагуляция, фундус-суреттер.

Кіріспе

Диабеттік ретинопатия (ДР) қант диабетімен ауыратын науқастарда жиі кездесетін көз ауруы, ол көру қабілетінің жоғалуының негізгі себептерінің бірі. ДР ерте кезеңдерде

анықталса, оның дамуын тоқтатуға немесе баяулатуға болады, ал дәл диагностикалау көруді сақтап қалуға мүмкіндік береді. Бұл әдебиеттік шолудың мақсаты – диабеттік ретинопатияны диагностикалауда қолданылатын қазіргі заманауи әдістер мен технологияларды талдау. Әсіресе, терең оқыту және бейімделген нейрондық желілердің қолданылуы қарастырылады. Мысалы, авторлар [1–3] мақалада диабеттік ретинопатияны диагностикалауға бағытталған терең оқыту үлгілерін әзірлеу үшін кескінді өңдеу әдістерін пайдалану талқыланады. Көз түбінің фотосуреттерін талдайтын және дәл диагноз қою үшін қажетті негізгі үлгілерді танитын нейрондық желілерге назар аударылады. Арнайы өңдеу әдістері көрсетілмегенімен, кескінді жақсарту, қан тамырлары мен зақымдануларды бөлектеу үшін сегменттеу және құрылым мен түс сияқты ерекшеліктерді алу күтілуде. Зерттеу толық модельді оқытуға мүмкіндік беретін «Бразилиялық көп мақсатты офтальмология деректер жинағына» негізделген. Мақалада сонымен қатар диабеттік ретинопатия мен онымен байланысты ауруларды диагностикалауға арналған модельдерді оқытудың үш тәсілі баяндалады, диагностикалық дәлдікті арттыруда кескінді өңдеу әдістерінің маңыздылығы көрсетіледі. Келесі [2] жұмыста диабеттік ретинопатия үшін лазерлік коагуляцияны емдеуді жақсарту үшін көз түбінің кескіндерін талдауда терең нейрондық желілерді пайдалануды зерттейді. Зерттеу екі нейрондық желіні пайдаланады: біріншісі – көз түбінің кескіндеріндегі анатомиялық құрылымдарды анықтау үшін, екіншісі – лазерлік емдеуді қажет ететін ісіну аймақтарын анықтау үшін. Екі желінің шығыстарын біріктіру арқылы әдіс оңтайлы емдеу аймақтарын дәл анықтауға, медициналық араласулардың дәлдігін арттыруға мүмкіндік береді. Қысқаша айтқанда, бұл зерттеуде қолданылатын әдістер анатомиялық құрылымдар мен ісіну аймақтарын шығаруға баса назар аудара отырып, көз түбінің кескіндерін талдау үшін терең нейрондық желілерді қолдануды қамтиды. Бұл нәтижелерді біріктіру диабеттік ретинопатия үшін лазерлік коагуляцияны емдеудің дәлдігін арттыруға бағытталған. Авторлар [3–7] диабеттік ретинопатияның (DR) автоматтандырылған диагностикасы үшін деректерді жинау және өңдеудің жүйелі тәсілі сипатталған, ол бірнеше негізгі қадамдарды қамтиды. Кескінді алу клиникалық маңыздылықпен кескін сапасын қамтамасыз ете отырып, офтальмологиялық тәжірибелермен бірлесіп, офтальмоскопия көмегімен жүзеге асырылады. Содан кейін кескіндер әзірленген алгоритм арқылы орталықтандырылған өңдеуге арналған арнайы серверге жүктеледі, мұнда графикалық интерфейс медицина мамандары үшін жүктеп алуды жеңілдетеді. Жүктелген кескіндер оптикалық диск және зақымданулар сияқты DR негізгі ерекшеліктерін анықтауға бағытталған морфологиялық алгоритмдерді пайдалана отырып, бірқатар өңдеу қадамдарынан өтеді. Мамандар бұрын қолмен тексеруді қажет ететін процесті автоматтандыру арқылы диагностикалық дәлдігі мен тиімділігін арттыратын терең оқыту әдістері мен нейрондық желілерді пайдалана отырып, автоматтандырылған талдауға басты назар аударылады. Бүкіл процесс диабеттік ретинопатияны ерте анықтауды жақсартуға бағытталған, ол қант диабеті және соған байланысты көру қабілетінің жоғалуын азайтуға көмектеседі, осылайша емдеудің тиімді нәтижелерін береді.

Келесі жұмыста [4] терең оқыту және кескінді алдын ала өңдеу әдістерін қолдана отырып, диабеттік ретинопатияны (DR) болжау бойынша бірнеше негізгі қорытындылар берілген. Біріншіден, ол көрудің нашарлауын болдырмау үшін DR ерте анықтау маңыздылығын көрсетеді, бұл емнің нәтижелерін және пациенттердің өмір сүру сапасын айтарлықтай жақсартып алады. Екіншіден, зерттеу дәл талдау үшін шуды азайту және айқындықты арттыру арқылы кескін сапасын жақсартатын Sobel, Winer, Gauss және жергілікті емес орташа сүзгілер сияқты кескінді алдын ала өңдеудің әртүрлі әдістерінің тиімділігіне назар аударады [5]. Терең конволюциялық нейрондық желі (CNN) кескінді өңдеуден кейін DR болжау үшін қолданылады, аурумен байланысты күрделі үлгілерді ашады. Алдын ала өңдеу және CNN болжау әдістерінің үйлесімі кескін сапасын және болжау дәлдігін арттыра отырып [6–7], DR талдауының перспективалы тәсілін көрсетеді. Зерттеу нәтижелері денсаулық сақтау провайдерлеріне көмектесетін және емдеу нәтижелерін жақсартатын және аурумен байланысты ауыртпалықты азайтатын DR үшін

компьютерлік диагностикалық жүйелердің әлеуетін көрсетеді. Қорытындылай келе, мақалада кескінді алдын ала өңдеу әдістері мен терең оқыту үлгілерінің интеграциясы диабеттік ретинопатияны болжау мен диагностикасының дәлдігін айтарлықтай жақсартып, медициналық шешімдерді жақсартуға жол ашатынын айтады. Авторлар [4–10] алдын ала өңдеу әдістері және CNN моделі сияқты әдістемелерге назар аудара отырып, диабеттік ретинопатияны болжауды зерттеу үшін қандай ретинальды кескін жиынтығы пайдаланылғаны көрсетілмеген. Онда CNN моделі бақыланатын оқыту үшін қажетті таңбаланған деректер жиынында оқытылатыны айтылады, бірақ бұл деректер жиынының нақты атауы немесе көзі көрсетілмейді. Алдын ала өңдеу әдістерінің маңыздылығына баса назар аударылғанымен, пайдаланылған деректер жиынының сипаттамалары немесе шығу тегі ескерілмейді, бұл оны идентификациялауды шектейді. Қорытындылай келе, қарастырылған жұмыстарда қолданылатын әдістерге назар аудара отырып, белгілі бір кескіндер жиынтығы туралы ақпарат берілмейді, бірақ мұндай зерттеулердегі жалпы деректер жиыны туралы ақпарат алу үшін EyePACS немесе Kaggle диабеттік ретинопатияны анықтау сияқты жалпыға қолжетімді жинақтарды іздеуге болады, олар жиі кездеседі және ДР зерттеулерінде қолданылады.

Авторлардың [6–7] мақаласында диабеттік көз ауруларын (DED) жіктеу үшін бірнеше жалпыға қолжетімді деректер жинақтары пайдаланылады. Зерттеуде Messidor, Messidor-2, DRISHTI-GS және GitHub жинақтарының суреттері пайдаланылады, оларда ретинопатия дәрежесі және макулярлы ісіну қаупі бар офтальмолог таңбаланған кескіндер бар. Әрбір сурет қан кетулер мен микроаневризмалар сияқты белгілі бір зақымдардың болуына негізделі таңбалады. Keras ImageDataGenerator көмегімен геометриялық түрлендірулерді (айдау, айналдыру және қию) қоса алғанда, жаттығу деректерінің өлшемін үлкейту үшін деректерді кеңейту әдістері қолданылады. Қалыпты үлгілер арасында ЖСҚ жеңіл жағдайларын анықтауға ерекше назар аударылады, кескіндердегі нәзік айырмашылықтарды ажырату үшін үлгілерді үйрету үшін пайдаланылатын деректер жиынының маңыздылығын көрсетеді. Сонымен, зерттеу диабеттік көз ауруларын анықтауға бағытталған терең үлгілердің өнімділігін жақсарту үшін көптеген деректер жинақтары мен алдын ала өңдеу әдістерін пайдалануды көрсетеді. Авторлардың [6–7] мақаласы әртүрлі әдістерді қолдана отырып, диабеттік көз ауруларын (ДР) анықтауды жақсартудың жүйелі тәсілін сипаттайды [8–11]. Негізгі әдістерге көз түбінің сапасын жақсартуға арналған кескінді өңдеудің дәстүрлі әдістері, қызығушылық аймақтарын оқшаулау үшін сегменттеу, аудару, айналдыру және Keras ImageDataGenerator арқылы кескінді қию арқылы деректерді ұлғайту жатады. Зерттеу сонымен қатар DED классификациясы үшін ResNet50, VGG-16 және Xception сияқты алдын ала дайындалған конволюционды нейрондық желілерді (CNN) пайдаланады [12–15], сонымен қатар салыстыру үшін өзінің CNN архитектурасын үйретеді. Гиперпараметрлерді баптау олардың үлгі өнімділігіне әсерін бағалайды және эксперимент нәтижелері дәлдік, ерекшелік және сезімталдық үшін талданады. Қорытындылай келе, дәстүрлі өңдеу әдістері мен жаңа CNN архитектурасының үйлесімі ЖСҚ жіктеу тапсырмаларында ең жақсы нәтижелерді көрсетеді, бұл осы ауруларды ерте анықтауды жақсартуға көмектеседі.

Материалдар мен әдістер

Диабеттік ретинопатияны (DR) жіктеу тапсырмасында болжаулардың жоғары дәлдігі мен негізділігін қамтамасыз ететін бірқатар әдістер мен алгоритмдер, нейрондық желі қолданылды. Диабеттік ретинопатия – көздің түбін бейнелеу арқылы диагноз қойылған тордың прогрессивті ауруы [16]. Қиындық аурудың әртүрлі кезеңдері арасындағы көрнекі ұқсастықта жатыр, ол күрделі кескінді талдау мен деректерді өңдеу әдістерін қажет етеді. Кескіндерді жіктеу үшін заманауи машиналық оқыту әдістері қолданылды [17]. Модельді жалпылауды жақсартатын, олардың көлемін және өзгермелілігін арттыру үшін деректерді кеңейту (айналдыру, масштабтау, жылжу, жарықтықты өзгерту) қолданылды. Оқыту бес сыныптың ықтималдығын болжау үшін

шығыс softmax қабаты бар `init_model` арқылы инициализацияланған терең конволюциялық нейрондық желіні қолдану арқылы жүзеге асырылды. Қатені азайту үшін кросс-энтропия жоғалту функциясы (`CrossEntropyLoss`) пайдаланылды [18].

Оңтайландыру оқу үдерісін тұрақтандыратын қадамдық оқыту жылдамдығын жоспарлаушымен (`StepLR`) толықтырылған Adam алгоритмімен орындалды. Өнімділікті бағалау үшін класстық теңгерімсіздікті есепке алу үшін квадраттық салмақтары бар Коэннің Каппа метрикасы пайдаланылды. Дәлдік, еске түсіру және F1 ұпайлары да талданған. Ерте тоқтату шамадан тыс орнатудың алдын алды, ал ең жақсы салмақтарды сақтау нәтижелердің қайталануын қамтамасыз етті [19].

Бекітілген қатпарлар саны бар кросс-валификация үлгінің беріктігін тексерді. Бұл әдістерді қолдану тұрақты өнімділікті қамтамасыз етті және одан әрі оңтайландыру бағыттарын анықтады, соның ішінде сыныптық теңгерімсіздікпен күресу [20].

1. Кросс-валидация

Кросс-валидация күрделілік пен деректер шектеулеріне қарамастан үлгі өнімділігін сенімді бағалауды қамтамасыз етті. ДР классификациясы контекстінде:

- ♦ Кросс-валидация аурудың неғұрлым ауыр кезеңдері (мысалы, 3 және 4
- ♦ сыныптар) сирек кездесетін теңгерімсіз класс таралуының әсерін азайтты [15].
- ♦ Модельдің әрбір к-қатардағы орташа өнімділігі оның жаңа деректерге жалпылау мүмкіндігі туралы объективті түсінік береді:

$$M = \frac{1}{k} \sum_{i=1}^k M_i, \quad (1)$$

мұндағы M_i – i -ші қабаттағы метрика. Бұл әсіресе маңызды, өйткені жеңіл кезеңді ауыр кезең ретінде қате жіктеу артық емдеуге әкелуі мүмкін, ал ауыр кезеңді өткізіп жіберу кеш араласуға әкелуі мүмкін.

2 Конволюция. Модельдегі конволюциялық қабаттар көз түбі кескіндерін талдауда маңызды рөл атқарды және жергілікті ерекшеліктерін анық көрсетеді, мысалы: диабеттік ретинопатияға тән ісіну, қан кету және микротамырлық ауытқулар конвульсиялар арқылы автоматты түрде шығарылды [17]:

$$(x, y) = \sum_{i=1}^m \sum_{j=1}^n K(i, j) \cdot I(x + i, y + j), \quad (2)$$

мұнда, $I(x+i, y+j)$ – бастапқы кескіннің пиксельдік мәні (кіріс бейненің қарқындылығы); $K(i, j)$ – тұқыртпа ядросы немесе фильтрдің салмақ коэффициенттері; m, n – сүзгінің (ядроның) биіктігі мен ені; (x, y) – шығыс кескіннің (feature map) координаталары. Бұл операция нәтижесінде бастапқы кескіннің ерекшеліктері (мысалы: жиектер, текстуралар) бөлініп алынады.

3. Softmax функциясы. DR сатысын 5 сыныптың біріне жіктеу үшін модельдің шығыс мәндерін сыныптардың әрқайсысына жататын ықтималдықтарға түрлендіретін softmax функциясы қолданылды:

$$P(y = k | x) = \frac{\exp(z_k)}{\sum_{j=1}^C \exp(z_j)}, \quad (3)$$

мұнда, $P(y=k | x)$ – берілген кіріс x үшін оның k -сыныпқа жату ықтималдығы; z_k – модельдің соңғы қабатындағы k -сыныпқа сәйкес келетін логит (шығыс активацияға дейінгі мән); C – сыныптар саны (мысалы, диабеттік ретинопатияны бес сатыға жіктеу кезінде $C=5$); $\exp(\cdot)$ – экспоненциалдық функция, ол барлық логиттерді оң мәндерге түрлендіреді.

Бұл модельдік болжамдарды «ретинопатияның жоқтығынан» (0-сынып) «ауыр кезеңге» (4-сынып) дейінгі кезеңдердің ықтималдығы ретінде түсіндіруге мүмкіндік берді. Softmax

модельге белгісіздікті азайтып, ең жоғары ықтималдығы бар сыныпқа назар аударуға көмектеседі [18–19].

4. Айқас энтропия жоғалту функциясы

DR жіктеу мәселесі теңдестірілмеген сыныптарды қамтитындықтан, кросс-энтропия жоғалту функциясы шынайы класс белгілері мен болжамды ықтималдықтар арасындағы сәйкессіздікті азайтуға көмектесті:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^C y_{i,k} \log(\hat{y}_{i,k}), \quad (4)$$

мұндағы $y_{i,k}$, егер объект k класына жататын болса, 1 мәнін, ал басқаша жағдайда 0 мәнін қабылдайды. Бұл модельде сирек, бірақ маңызды сыныптарды дәл анықтауға мүмкіндік береді (мысалы, 4-сынып, DR ауыр сатысы).

5. Adam Optimizer

Модельді үйрету үшін Adam оптимизаторы пайдаланылды [21]. DR жіктеу мәселесінде ол жылдам және тұрақты конвергенцияға ықпал еткен градиенттердің адаптивті бақылауын қамтамасыз етті:

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}}. \quad (5)$$

Бұл деректердің біркелкі еместігіне байланысты градиенттер сирек болуы мүмкін күрделі көз түбінің кескіндерін талдау кезінде өте маңызды (мысалы, микроаневризмалар сияқты кішігірім зақымданулар сирек кездеседі).

6. Коэннің каппасы

Диабеттік ретинопатия диагностикалық тапсырмасында модель болжамдары мен негізгі шындық белгілері арасындағы келісімді бағалау үшін квадраттық салмақтары бар Коэннің Каппа метрикасы пайдаланылды [22]:

$$\kappa = \frac{p_o - p_e}{1 - p_e}. \quad (6)$$

Квадрат салмақтар:

$$w_{ij} = 1 - \left(\frac{i - j}{C - 1} \right)^2, \quad (7)$$

іргелес сыныптар арасындағы қателер (мысалы, 2 және 3) қашықтағы сыныптар арасындағы қателерден (мысалы, 0 және 4) аз жазаланғанын қамтамасыз етті. Бұл клиникалық мағынаға ие, өйткені жеңіл кезеңдер арасындағы ауысудағы қателер ауыр жағдайларды жіберіп алудан гөрі маңызды емес.

7. Ерте тоқтау

Егер валидация жинағындағы Коэннің Каппа метрикасы k дәуірде жақсармаса, шамадан тыс фитингтің алдын алу үшін жаттығуды тоқтату үшін ерте тоқтату қолданылды: егер $M_t - M_{t-k} < \epsilon$, онда жаттығу тоқтайды.

Бұл деректердегі шуылға шамадан тыс бейімделуді болдырмай, оңтайлы модельді оқытуды қамтамасыз етті.

8. Деректерді кеңейту

Деректерді кеңейту мыналарды қамтиды:

- ◆ Айналдыру (0): Көз түбінің бұрыштарының өзгеруін ескере отырып, кескіндер кездейсоқ бұрышқа айналдырылды.

♦ Масштабтау: Көру өрісіндегі айырмашылықтарды имитациялау үшін кескіндердің өлшемін өзгерту.

♦ Жарықтықтың өзгеруі: түсіру кезінде жарықтандырудың өзгермелілігін ескереді.

Бұл әдістер модельге нақты жағдайға бейімделуге және диабеттік ретинопатияның негізгі ерекшеліктерін жақсырақ көрсетуге мүмкіндік берді. Сипатталған әдістерді қолдану деректердегі қиындықтарды ескере отырып, диабеттік ретинопатияны диагностикалау мәселесін тиімді шешуге мүмкіндік берді, мысалы, класстық теңгерімсіздік, шағын жергілікті белгілер және аурудың кезеңдері арасындағы ұқсастықтар. Таңдалған тәсілдердің математикалық негіздемесі олардың дұрыстығын және клиникалық маңызды нәтижелерді беру мүмкіндігін растайды.

Деректер жинағы және олардың сипаттамасы. Осы зерттеудің бөлігі ретінде оқу және сынақ жиынтықтарына бөлінген көз түбінің кескіндерін қамтитын деректер жиынтығы пайдаланылды. Жаттығу жиынында 35 126 сурет, ал сынақ жиынында 3 662 сурет болды. Әрбір суретте диабеттік ретинопатияның кезеңдерін анықтайтын бес санаттың біріне сәйкес келетін диагностикалық белгі болды: 0 – ауру жоқ, 1 – ерте кезең, 2 – орташа кезең, 3 – ауыр кезең, 4 – пролиферативті кезең (1-сурет).

Оқыту жиынындағы сабақтардың бөлінуі:


- ♦ 0-сынып (ретинопатия жоқ): 25 810 сурет (73,5%)
- ♦ 1-сынып (бастапқы кезең): 2443 сурет (7,0%)
- ♦ 2-сынып (орташа кезең): 5292 сурет (15,1%)
- ♦ 3-сынып (ауыр кезең): 873 сурет (2,5%)
- ♦ 4-сынып (пролиферативті кезең): 708 сурет (2,0%)

Сынақ топтамасындағы деректердің бөлінуі:

- ♦ 0-сынып (ретинопатия жоқ): 1805 сурет (49,3%)
- ♦ 1-сынып (бастапқы кезең): 370 сурет (10,1%)
- ♦ 2-сынып (орташа кезең): 999 сурет (27,3%)
- ♦ 3-сынып (ауыр кезең): 193 сурет (5,3%)
- ♦ 4-сынып (пролиферативті кезең): 295 сурет (8,0%)



Сурет 1 – Көз түбі кескіндерінің сыныптар бойынша жіктелуі



Сурет 2 – Сыныптардағы кескіндердің үлестірімінің гистограммасы

Бірдей көз түбінің 3-сурет екі нұсқасы көрсетілген: бастапқы сурет (сол жағында) және алдын ала өңделген сурет (оң жағында). Бастапқы сурет деректерді өңделмеген күйінде көрсетеді, ал өңделген сурет бірқатар сапа жақсарту кезеңдерінен өткен, бұл деректерді дәл интерпретациялау үшін маңызды.



Сурет 3 – Қалыпты және ДР кездесетін кескіндер

Алдын ала өңдеу бірнеше негізгі кезеңдерден тұруы мүмкін:

Айқындық деңгейін күшейту. Көз түбінің маңызды құрылымдарын, мысалы, қан тамырларын немесе тор қабығының зақымдануларын анық көрсету үшін суреттің контрастын арттыру. Бұл әсіресе диабеттік ретинопатия сияқты ауруларды диагностикалауда маңызды.

Жарықтың әсерін тұрақтандыру. Жарықтандырудың теңсіздігін азайту, бұл суреттердің анықтығын қамтамасыз етеді.

Артефактілер мен шуылдарды тегістеу. Суретте пайда болатын қажетсіз шуылдар мен артефактілерді жою, бұл суреттердің сапасын арттырып, кейінгі талдауға дайын етеді.

Түстік балансын өзгерту. Суреттегі маңызды құрылымдарды айқындау және оны түсінікті көрсету үшін түстік балансты реттеу.

Бұл қадамдар көз түбінің ауруларын, мысалы, диабеттік ретинопатия мен глаукоманы диагностикалау үшін маңызды компьютерлік көру тапсырмаларында қолданылатын суреттерді дайындау үшін қажет. Суреттердің дұрыс өңделуі автоматтандырылған диагностикалық жүйелердің дәлдігін және сенімділігін айтарлықтай арттырады, бұл айқын әрі ақпаратты деректер алуға мүмкіндік береді.

Деректерді өңдеу:

1. Класстың теңгерімсіздігі. Жаттығулар кешенінде жалпы деректердің 73,5%-ын құрайтын 0-сынып (ретинопатия жоқ) басым, ал ауыр кезеңдері (3 және 4-сыныптар) айтарлықтай аз, сәйкесінше 2,5% және 2,0%-ды көрсетеді 2-сурет. Сыныптың теңгерімсіздігін есепке алу үшін салмақты жоғалту функциялары және деректерді көбейту әдістері қолданылды.

2. Деректерді көбейту. Жаттығу деректерінің өзгермелілігін арттыру үшін кескінді айналдыру, масштабтау, жылжу және жарықтықты өзгерту сияқты әдістер қолданылды. Бұл әдістер модельді жалпылауды жақсартты және көз түбі кескіндерінің өзгергіштігін ескерді.

3. Сынақ үлгісінің мақсатын айқындау. Оқу процесінде пайдаланылмаған деректер бойынша модельдің өнімділігін объективті бағалау үшін тест жинағы бөлек бөлінді.

Пайдаланылған деректер жинағы ретинопатиясыз жағдайлар басым және ауыр кезеңдері сирек кездесетін нақты клиникалық тәжірибеге жақын жағдайларда ұсынылған модельдің өнімділігін зерттеуге мүмкіндік берді. Бұл ерекшеліктер класстық теңгерімсіздікпен тиімді күресетін және сирек, бірақ клиникалық маңызды жағдайлардың жіктелуінің дәлдігін жақсартатын әдістердің қажеттілігін көрсетті.

Нәтижелер мен талқылау

Зерттеуде бейнелерді классификациялау үшін EfficientNetB0 нейрондық желісі қолданылды. Бұл әдіс алдын ала оқытылған модельдерге негізделген Transfer Learning тәсілін пайдалануды қамтиды. Оқыту процесінде екі кезең орындалды: базалық қабаттарды қатыру және жоғарғы қабаттарды ашып, қосымша бейімдеу. EfficientNetB0 моделінің гиперпараметрлері алдын ала тәжірибе арқылы таңдалды. Оқыту жылдамдығы, батч мөлшері, оптимизатор түрі және регуляризация параметрлері бірнеше эксперименттік конфигурацияда бағаланды. Торлы іздеу (grid search) және кездейсоқ іздеу (random search) әдістері арқылы ең тиімді комбинация таңдалды. Кросс-валидация нәтижелері модельдің тұрақтылығы мен қайта өндірілуін қамтамасыз етті, бұл зерттеу нәтижелерін басқа деректер жиынтықтарында бағалауға мүмкіндік береді. Модельдің генерализациясын жақсарту үшін аугментация әдістері енгізілді (айналдыру, масштабтау, қиғаштау және т.б.), ал оқыту тиімділігін арттыру үшін Adam оптимизаторымен ReduceLROnPlateau және EarlyStopping сияқты коллбэктер қолданылды. Соңғы қабатта softmax активациясы арқылы бейнелерді мультикласстық классификациялау жүзеге асырылды.

Нәтижелер Precision, Recall, F1-Score және Accuracy метрикаларымен

бағаланды. Бұл тәсіл деректерді дәл және тиімді классификациялауға мүмкіндік берді. Эксперименттер барысында модельдің жұмысын бағалау үшін үш класстан тұратын деректер жиынтығы қолданылды: Train, Test, және Val. Негізгі метрикалар – Precision, Recall және F1-Score – әр класс үшін де, сондай-ақ жалпы түрде (қорытынды метрикалар) есептелді. Нәтижелер 4-суретте көрсетілген.

Results by Class:				
Class	Precision	Recall	F1-Score	Support
Test	0.65	0.60	0.62	615
Train	0.85	0.90	0.87	5004
Val	0.68	0.65	0.66	619
Summary Metrics:				
	Precision	Recall	F1-Score	Support
Accuracy				0.80
Macro Avg	0.73	0.72	0.72	
Weighted Avg	0.81	0.85	0.83	

Сурет 4 – Кластар бойынша классификация нәтижелері және қорытынды метрикалар

Нәтижелерді талдау

1. Кластар бойынша. Train класындағы метрикалар Test және Val кластарымен салыстырғанда айтарлықтай жоғары, бұл деректердің дисбалансын немесе модельдің жалпылау қабілетінің жетіспеушілігін көрсетуі мүмкін. Мысалы, Train үшін Precision 0.85 болса, Test және Val үшін сәйкесінше 0.65 және 0.68.

2. Қорытынды метрикалар. Accuracy 80%-ға жетіп, модельдің жалпы дәлдігі жоғары екендігін көрсетті. Орташа өлшенген Precision (0.81), Recall (0.85) және F1-Score (0.83) көрсеткіштері де модельдің тиімділігін растайды.

3. Қорытынды. Жаттықтыру деректері бойынша жоғары дәлдікке қарамастан, Test және Val кластарында салыстырмалы түрде төмен метрикалық моделдің артық үйренуіне

(overfitting) нұсқайды. Нәтижелерді жақсарту үшін деректерді теңестіру, гиперпараметрлерді жақсарту және қосымша регуляризация әдістерін қарастырылады.

Бұл экспериментте екі түрлі әдіс бойынша EfficientNetB0 моделінің өнімділігі тексерілді: бірінші әдіс барлық қабаттарды қатырып қояды және тек соңғы қабаттармен жұмыс істеуді қолданса, екінші әдіс жоғарғы қабаттарды бастапқы оқытудан кейін ашып, модельді одан әрі бейімдеу (fine-tuning) процесін жүргізді.

Нәтижелерді салыстыру:

1. Precision, Recall және F1-Score метрикалары бойынша екінші әдіс айтарлықтай жоғары нәтижелер көрсетті, әсіресе сынақтық және валидациялық деректерде. Әдіс 2 жоғарғы қабаттарды ашу арқылы модельдің күрделілігін арттырды және нақты деректерге жақсы бейімделуін қамтамасыз етті (5-сурет).

Метрика	Әдіс 1 (Қатырып қою)	Әдіс 2 (Жоғарғы қабаттарды ашу)
Precision (Train)	0.85	0.85
Precision (Test)	0.65	0.75
Precision (Val)	0.63	0.71
Recall (Train)	0.90	0.88
Recall (Test)	0.60	0.74
Recall (Val)	0.65	0.73
F1-Score (Train)	0.87	0.86
F1-Score (Test)	0.62	0.74
F1-Score (Val)	0.64	0.72
Accuracy	0.80	0.80
Macro Average	0.72	0.77
Weighted Average	0.74	0.81

Сурет 5 – Нәтижелерді салыстыру

2. Accuracy көрсеткіші екі әдіс бойынша да бірдей болды (0.80), бірақ Macro Average және Weighted Average метрикаларында екінші әдіс айтарлықтай жақсы нәтижеге жетті (0.77 және 0.81 сәйкесінше 0.72 және 0.74).

Екінші әдіс, яғни жоғарғы қабаттарды ашып, модельді қосымша бейімдеу (fine-tuning), тиімдірек болып шықты. Бұл әдіс тестілік және валидациялық деректерде жоғары нәтижелер берді, сол арқылы артық үйрету мәселесін азайтуға мүмкіндік берді және жалпы модельдің жалпы тиімділігін арттырды. Осылайша, екінші әдіс модельдің тиімділігі мен дәлдігін жақсартуға мүмкіндік берді.

Қорытынды

Зерттеу нәтижелері бойынша диабеттік ретинопатияны анықтау мен диагностикалау саласындағы қазіргі заманғы әдістердің тиімділігі айқын көрінді. Әсіресе, терең оқыту әдістері, оның ішінде Convolutional Neural Networks (CNN) және EfficientNet алдын ала оқытылған модельдері, диабеттік ретинопатияның әртүрлі кезеңдерін жоғары дәлдікпен анықтауға мүмкіндік береді. Сурет аугментациясы және алдын ала өңдеу әдістері, мысалы, нормализация мен шу мен контрастты арттыру, модельдің тиімділігін арттыруға оң әсер етеді.

Зерттеулерде қолданылған әдістердің арасында көрініс деңгейінде үлкен айырмашылықтар болмағанымен, модельдерді тексеру және баптау кезінде (fine-tuning) жоғары нәтижелерге қол жеткізуге болады. Сонымен қатар, қолданылған кері шақыру (callback) функциялары, яғни EarlyStopping және ReduceLROnPlateau, оқу процесін оңтайландыруға және модельдің артық үйренуден (overfitting) сақталуына көмектеседі. Алынған нәтижелер терең оқыту әдістерінің диабеттік ретинопатияны анықтауда жоғары тиімділігін көрсетті. Сурет аугментациясы мен алдын ала өңдеудің қолданылуы модельдің дәлдігін арттырды, ал EfficientNet және CNN модельдері жоғары нәтижелерге қол жеткізді. Кері шақыру (callback) функциялары

(EarlyStopping, ReduceLROnPlateau) оқу процесін оңтайландырып, артық үйренудің алдын алды. Алайда, модельдердің жалпы тұрақтылығын қамтамасыз ету үшін қосымша деректер және түсіндірмелі жақсартулар қажет.

Зерттеу барысында бірқатар кемшіліктер анықталды, соның ішінде деректер көлемінің шектеулілігі мен модель нәтижелерін түсіндірудегі қиындықтар. Бұл мәселелерді шешу үшін болашақта деректер жиынтықтарын кеңейту және модельдердің түсініктілігін арттыру бағытында қосымша зерттеулер жүргізу қажет. Жалпы алғанда, терең оқыту әдістері диабеттік ретинопатияны ерте кезеңдерде анықтауға тиімді құрал ретінде қолданыла алады және бұл әдістерді клиникалық практикаға енгізу үшін қосымша зерттеулер мен тәжірибелік тексерулер қажет.

ӘДЕБИЕТТЕР

1 Mehmet, Şahin., Omer, Faruk, Beyca. Diabetic Retinopathy Diagnosis with Image Processing (2024). <https://doi.org/10.1109/siu61531.2024.10601116>.

2 Nikita, S., Demin., N., Yu., Ilyasova., Rustam, Paringer. Automatic Selection of the Optimal Zone for Laser Exposure According to the Fundus Images for Laser Coagulation (2023). <https://doi.org/10.18287/jbpe23.09.040308>.

3 Agnieszka, Cisek., Karolina, Korycinska., Leszek, Pyziak., Marzena, Malicka., Tomasz, Wiecek., Grzegorz, Gruzal., K., Szmuc., Jozef, Cebulski., Mariusz, Spyra. Algorithm-based diagnostic application for diabetic retinopathy detection. arXiv.org. abs/2312.00529 (2023). <https://doi.org/10.48550/arxiv.2312.00529>.

4 Balaji, S., Karthik, B., Gokulakrishnan D. Prediction of Diabetic Retinopathy using Deep Learning with Preprocessing. EAI Endorsed Transactions on Pervasive Health and Technology, 10 (2024). <https://doi.org/10.4108/eetpht.10.5183>.

5 Rubina, Sarki, Khandakar, Ahmed, Hua, Wang... Yanchun, Zhang... Jiangang, Ma., Kate, N., Wang. Image Preprocessing in Classification and Identification of Diabetic Eye Diseases. Data Science and Engineering, 6(4), 1–17 (2021). <https://doi.org/10.1007/S41019-021-00167-Z>.

6 Onesinus, Saut, Parulian, Jufriadif, Na'am. Advanced Filtering and Enhancement Techniques for Diabetic Retinopathy Image Analysis. Journal Medical Informatics Technology, 69–75 (2024). <https://doi.org/10.37034/medinftech.v2i3.40>.

7 Imtiyaz, Ahmad, Vibhav, Prakash, Singh, Manoj, Madhava, Gore. Detection of Diabetic Retinopathy Using Discrete Wavelet-Based Center-Symmetric Local Binary Pattern and Statistical Features. Deleted Journal (2024). <https://doi.org/10.1007/s10278-024-01243-2>.

8 Sagar, Zanjad. Diabetic Retinopathy Detection from Retinal Images. Indian Scientific Journal Of Research In Engineering And Management, 08(06), 1–5 (2024). <https://doi.org/10.55041/ijrem35218>.

9 Mage, Usha, U., Subburaj, T., Hemanth, K.J. Innovative AI Solution for Diabetic Retinopathy Health. International Journal of Advanced Research in Science, Communication and Technology, 10–13 (2024). <https://doi.org/10.48175/ijarsct-19003>.

10 Kalindhu Navanjana De Silva, K., Sanduni Kumari Lanka Fernando, T., Lakshan Sandaruwan Jayasinghe, L.D., Dinuka Sandaruwan Jayalath, M.H., Kasun Karunanayake, B.A.P. Madhuwantha. Towards Accurate Detection of Diabetic Retinopathy Using Image Processing and Deep Learning. International Journal of Advanced Computer Science and Applications, 15(9) (2024). <https://doi.org/10.14569/ijacsa.2024.0150986>.

11 Mahesh, M.R., Rohith, S. Analysis of Diabetic Retinopathy in Retinal Fundus Images, 1–5 (2024). <https://doi.org/10.1109/ickecs61492.2024.10616880>.

12 Balaji., S., Karthik, B., Gokulakrishnan, D. Prediction of Diabetic Retinopathy using Deep Learning with Preprocessing. EAI Endorsed Transactions on Pervasive Health and Technology, 10 (2024). <https://doi.org/10.4108/eetpht.10.5183>.

13 Shrimali, S. Image Filtering and Utilization of Deep Learning Algorithms to Detect the Severity of Diabetic Retinopathy. International Conference on Communication Systems and Network Technologies, 202–207 (2023). <https://doi.org/10.1109/CSNT57126.2023.10134680>.

14 Mamyrbayev, O.Zh., Pavlov, S.V., Momynzhanova, K.R. Development of an expert system based on fuzzy logic for early diagnosis of glaucoma. Herald of the Kazakh-British technical university, 21(3), 37–47 (2024) (In Kazakh). <https://doi.org/10.55452/1998-6688-2024-21-3-37-47>.

15 Imane, Mehidi. Pre-processing Techniques: A Review for Retinal Image Segmentation (2024). <https://doi.org/10.1109/iceecac61226.2024.10576331>.

16 Thirawat, Saengarun, Niwat, Angkawisittpan, Adisorn, Nuan-On., Guifen, Lyu, Xiaoli, Fu., Sivarit, Sultornsanee. The Development for Diabetic Retinopathy Lesion Detection on Fundus Photography (2024). <https://doi.org/10.1109/ieecon60677.2024.10537869>.

17 Surmayanti, Sumijan, Sumijan, Saiful, Bukhori. Identification of Diabetic Retinopathy Using the Extraction Method on Fundus Images, 333–340 (2024). <https://doi.org/10.1109/icoict61617.2024.10698276>.

18 Pranoti, Nage, Sanjay, Shitole. Analysis of Image Processing Techniques for Retinal Fundus Images in Detection of Ophthalmic Disease Screening, 1–4 (2023). <https://doi.org/10.1109/icccnt56998.2023.10306704>.

19 Vignesh., R., Muthukumaran, N. Detection of Diabetic Retinopathy Image Analysis using Convolution Graph Neural Network, 921–929 (2023). <https://doi.org/10.1109/ICICT57646.2023.10134388>.

20 Abisha, J., Jeba, P.S. Detection of Diabetic Retinopathy by Using Convolutional Neural Network (2023). <https://doi.org/10.59544/mine9624/ngcesi23p89>.

21 Farzaneh, Nikbakhtsarvestani, Shahryar, Rahnamayan, Mehran, Ebrahimi. Opposition-based Multi-Objective ADAM Optimizer (OMAdam) for Training ANNs, 1–10 (2024). <https://doi.org/10.1109/cec60901.2024.10612083>.

22 Alexandra de Raadt, Matthijs J. Warrens., Roel Bosker, Henk, A.L., Kiers. Kappa Coefficients for Missing Data. Educational and Psychological Measurement, 79(3), 558–576 (2019). <https://doi.org/10.1177/0013164418823249>.

¹Yesmukhamedov N.S.,

PhD student, ORCID ID: 0009-0006-0652-3082,

e-mail: yesmukhamedov.yeskendyr@gmail.com

¹Sapakova S.Z.,

PhD, Associate Professor, ORCID ID: 0000-0001-6541-6806,

e-mail: sapakovasz@gmail.com

²Kozhamkulova Zh. Zh.,

PhD, Associate Professor, ORCID ID: 0000-0002-3901-7809,

e-mail: zh.kozhamkulova@au.es.kz

³Daniyarova D.,

PhD, Associate Professor, ORCID ID: 0000-0002-6833-6462,

e-mail: duriya.daniyarova@mail.ru

¹Armankyzy R.,

MSc, Lecturer, ORCID ID: 0009-0009-2236-559X,

e-mail: armankyzyrenata@gmail.com

¹International University of Information Technologies, Almaty, Kazakhstan

²Almaty University of Power Engineering and Telecommunications after Gumarbek Daukeev,
Almaty, Kazakhstan

³International Educational corporation, Almaty, Kazakhstan

METHODS FOR PRE-PROCESSING AND ANALYSIS OF FUND IMAGES FOR DETECTION OF DIABETIC RETINOPATHY

Abstract

This work is intended to study methods for pre-processing and analysis of fundus images for the detection of diabetic retinopathy. Diabetic retinopathy (DR) is a common eye disease in patients with diabetes, and its early diagnosis allows you to prevent vision loss. During the study, modern methods for processing and analyzing fundus images were used, including the EfficientNetB0 architecture based on Deep Learning. Image augmentation (rotation, scaling, cropping, contrast enhancement) and normalization methods were introduced for pre-processing. When using the EfficientNetB0 architecture, two approaches were tested: training the base layers and additional adaptation (fine-tuning) by opening the upper layers. The results were evaluated by metrics. The precision for the test set in the first method was 65%, and for the second method 75%. The accuracy of the validation set in the first method was 63%, and in the second method it reached 71%. The recall metric showed 60% for the test set in the first method, and 74% in the second method. In general, the fine-tuning method showed high performance. The use of these methods allows to improve the quality of image processing and classification for effective diagnosis of diabetic retinopathy.

The novelty of the study is the analysis of various methods of using and adapting the highly efficient EfficientNetB0 architecture. The results obtained allow to improve the quality of automated systems in DR diagnostics and increase the energy efficiency of the model. The proposed methods have high potential for early detection of eye diseases.

Keywords: diabetic retinopathy, machine learning, data analysis, laser coagulation, fundus images.

¹Есмухамедов Н.С.,

докторант, ORCID ID: 0009-0006-0652-3082,
e-mail: yesmukhamedov.yeskendyr@gmail.com

¹Сапакова С.З.,

к.ф.-м.н., ассоциированный профессор, ORCID ID: 0000-0001-6541-6806,
e-mail: sapakovasz@gmail.com

²Кожамкулова Ж.Ж.,

PhD, ассоциированный профессор, ORCID ID: 0000-0002-9780-9767,
e-mail: zh.kozhamkulova@aukes.kz

³Даниярова Д.Р.,

к.т.н., ассоциированный профессор, ORCID ID: 0000-0002-6833-6462,
e-mail: duriya.daniyarova@mail.ru

¹Арманкызы Р.,

м.т.н., лектор, ORCID ID: 0009-0009-2236-559X,
e-mail: armankyzyrenata@gmail.com

¹Международный университет информационных технологий, г. Алматы, Казахстан

²НАО «АУЭС им. Г. Даукеева», г. Алматы, Казахстан

³Международная образовательная корпорация, г. Алматы, Казахстан

ОПРЕДЕЛЕНИЕ ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ НА ОСНОВЕ ПРЕДВАРИТЕЛЬНОЙ ОБРАБОТКИ И АНАЛИЗА СНИМКОВ СЕТЧАТКИ ГЛАЗА

Аннотация

Данная работа посвящена исследованию методов предварительной обработки и анализа снимков сетчатки для определения диабетической ретинопатии (ДР). Диабетическая ретинопатия – это распространенное заболевание глаз у пациентов с диабетом, и ранняя диагностика этого заболевания помогает предотвратить потерю зрения. В ходе исследования были использованы современные методы обработки и анализа изображений, включая архитектуру EfficientNetB0, построенную на основе глубокого обучения. Для предварительной обработки были применены методы аугментации изображений (поворот, масштабирование, обрезка, повышение контраста) и нормализация. В ходе использования архитектуры EfficientNetB0 было испытано два подхода: заморозка базовых слоев модели и дообучение верхних слоев (fine-tuning). Результаты были оценены по меткам. В первом подходе точность (precision) на тестовой выборке составила 65%, во втором – 75%. Точность на валидационной выборке в первом случае составила 63%, во втором – 71%. Метрика обнаружения (recall) на тестовой выборке в первом подходе показала 60%, во втором – 74%. В целом методы fine-tuning показали лучшие результаты. Использование данных методов позволяет повысить качество обработки изображений и классификации для эффективной диагностики диабетической ретинопатии. Новизна исследования заключается в применении высокоэффективной архитектуры EfficientNetB0 и сравнении различных подходов к дообучению модели. Полученные результаты могут способствовать улучшению качества автоматизированных систем диагностики ДР и повышению энергоэффективности моделей. Предложенные методы обладают высоким потенциалом для раннего выявления глазных заболеваний.

Ключевые слова: диабетическая ретинопатия, машинное обучение, анализ данных, лазерная коагуляция, фундус-снимки.

Мақаланың редакцияға түскен күні: 19.12.2024